

Previsão do comportamento mecânico de formulações laboratoriais de solo-cimento para colunas de jet grouting com recurso a máquina de vetores de suporte

Joaquim Tinoco^{1,†}, António Gomes Correia², Paulo Cortez³

*Universidade do Minho, Departamento de Engenharia Civil, Azurém, P - 4800-058
Guimarães, Portugal*

RESUMO

Atualmente, no âmbito dos métodos de tratamentos de solos, o jet grouting (JG) é uma das tecnologias mais utilizadas, nomeadamente em importantes obras geotécnicas, caracterizando-se pela sua grande versatilidade. No entanto, no que respeita à previsão das propriedades mecânicas do novo material resultante do tratamento, a heterogeneidade dos solos e o elevado número de parâmetros envolvidos são os fatores que mais condicionam a existência de modelos racionais e precisos. O presente trabalho visa contribuir para o desenvolvimento de abordagens racionais e precisas com vista à previsão da resistência à compressão uniaxial e respetivo módulo de deformabilidade de formulações laboratoriais de JG. Para o efeito, recorreu-se à aplicação de técnicas de data mining, particularmente do algoritmo máquinas de vetores de suporte. Foi ainda realizada uma análise de sensibilidade detalhada, visando identificar as variáveis chave e qual o seu efeito no estudo das propriedades mecânicas de formulações laboratoriais de JG.

1. INTRODUÇÃO

Para servir como o solo de fundação, este deve apresentar as propriedades geotécnicas adequadas. No entanto, devido à crescente urbanização e industrialização, a disponibilidade de solos que satisfaçam tais requisitos é cada vez menor. Como consequência, há cada vez mais a necessidade de construir sobre solos moles caracterizados por elevada plasticidade, percentagem de finos e índice de vazios, baixa resistência e elevada compressibilidade (Liu et al., 2008). No sentido de dotar estes solos com as propriedades adequadas, um dos métodos mais populares consiste em misturar o solo natural com uma calda (normalmente de cimento), a qual é injetada diretamente no interior do mesmo. Este método de tratamento, designado Jet Grouting (JG) caracteriza-se pela sua grande versatilidade. Esta tecnologia permite melhorar as propriedades físicas e mecânicas de diversos tipos de solo (desde solos finos até solos granulares) e obter diferentes formas de tratamento (colunas, painéis, etc.). Além disso é economicamente atrativa quando comparada com métodos semelhantes. A tecnologia de JG

¹ Estudante de Doutoramento

[†] Autor para correspondência (jabinoco@civil.uminho.pt)

² Professor Catedrático

³ Professor Auxiliar

foi introduzida pela primeira vez pelos irmãos Yamakoda na década de 60 e desde então tem sido largamente utilizada em diversas partes do mundo (Xanthakos et al., 1994) na resolução de diversos tipos de problemas (Welsh e Burke, 1991; Gazaway e Jasperse, 1992).

Conceptualmente a tecnologia de JG tem por objetivo produzir uma mistura solo-cimento, também designada por *soilcrete*, caracterizada por um melhoramento das propriedades físicas e mecânicas (resistência e deformabilidade) em relação ao solo natural. Em termos de processo construtivo, o tratamento é efetuado através da injeção de uma calda (normalmente de cimento), eventualmente em conjunto com outros fluidos (ar e/ou água), a elevadas pressões e velocidade no interior do solo natural. Os fluidos são injetados através de pequenos bicos acoplados na extremidade de uma haste que, após introduzida até à profundidade pretendida é animada de movimento rotacional e lentamente removida até à superfície. Em função do número de fluidos injetados, existem atualmente três tipos de sistemas correntemente aplicados (Xanthakos et al., 1994): sistema de *jet simples*, sistema de *jet duplo* e sistema de *jet triplo*.

Apesar de largamente utilizada, nomeadamente em importantes obras geotécnicas, o dimensionamento da tecnologia de JG carece de abordagens racionais e precisas para a previsão das propriedades físicas e mecânicas do novo material resultante do tratamento. De facto, o seu dimensionamento, tanto em obras de grande envergadura como nas de pequena dimensão, é essencialmente realizado através de métodos empíricos (Croce e Flora, 2001; Kirsh e Wolfgang, 2001) e auxiliado pela experiência do respetivo construtor. A heterogeneidade do solo natural e o elevado número de variáveis envolvidas em todo o processo, as quais apresentam relações complexas ou mesmo de não linearidade entre si, estão entre os fatores que mais contribuem para tal cenário. Como resultado, e uma vez que tais métodos empíricos são frequentemente muito conservativos e de aplicabilidade limitada, a qualidade e a economia do tratamento podem ser comprometidos. Assim, e tendo presente o elevado potencial e versatilidade da tecnologia de JG, bem como o seu papel cada vez mais preponderante em importantes obras geotécnicas, torna-se evidente a necessidade de desenvolver métodos racionais e fiáveis para a previsão das propriedades físicas e mecânicas do material JG.

Algumas das expressões matemáticas existentes na literatura para previsão das propriedades mecânicas do material JG (Lee et al., 2005; Narendra et al., 2006; Nikbakhtan e Ahangari, 2010) resultam da aplicação de análises estatísticas tradicionais. Contudo, estas ferramentas apresentam limitações significativas no tratamento de dados de JG caracterizados por elevada complexidade. Atualmente, uma das melhores alternativas para lidar com problemas de elevada dimensionalidade e complexidade passa pela utilização de um processo automático, recorrendo à aplicação de ferramentas de inteligência artificial que analisa as linhas da base de dados e extrai padrões e/ou regras para os mesmos.

O processo de descoberta de conhecimento em base de dados (Fayyad et al., 1996) é um processo iterativo constituído por várias etapas. De acordo com a metodologia CRISP-DM as seguintes etapas devem ser contempladas (Chapman et al., 2000): 1 – conhecimento do problema; 2 – conhecimento dos dados; 3 – preparação dos dados; 4 – modelação (ou seja, data mining); 5 – avaliação; e 6 – desenvolvimento. É na fase 4, porventura uma das mais importantes, onde são aplicados os diferentes algoritmos de DM, cada um com as suas vantagens e limitações, tendo por objetivo inferir regras/padrões sobre os dados, através do mapeamento de *I* variáveis de entrada (variáveis dependentes) na variável de saída (variável independente). Alguns dos modelos de DM mais interessantes são as Redes Neurais Artificiais (RNAs) e as Máquinas de Vetores de Suporte (MVSs), caracterizadas pela sua flexibilidade e capacidade de aprendizagem não linear.

Tendo por base os diversos casos de sucesso da aplicação de ferramentas de DM, nomeadamente na área de Geotecnia (Miranda et al., 2011; Goh e Goh, 2007), perspectiva-se

um bom desempenho das mesmas quando aplicadas sobre dados de JG. Assim, no presente trabalho são aplicadas ferramentas de DM no desenvolvimento de uma abordagem racional para a previsão das propriedades mecânicas de Formulações Laboratoriais de Jet Grouting (FLJG). Para o efeito, foi treinada uma MVS para previsão da resistência à compressão uniaxial (Q_u) de FLJG ao longo do tempo. Nas estruturas geotécnicas onde os estados limite de utilização são requeridos, é também necessário conhecer as propriedades de deformabilidade do solo tratado. Assim, foram também treinadas MVSs para o estudo dos diferentes módulos de deformabilidade. Isto é, do módulo de elasticidade inicial (E_0), módulo de deformabilidade tangente a 50% da tensão de rotura ($E_{tg50\%}$), módulo de deformabilidade secante a 50% da tensão de rotura ($E_{se50\%}$) e módulo de deformabilidade máximo (E_{max}) de FLJG ao longo do tempo.

2. MÁQUINA DE VETORES DE SUPORTE

Fundamentado na teoria da aprendizagem estatística, as MVSs, do inglês *Support Vector Machine* foram desenvolvidas por Vapnik (2000), tendo inicialmente por objetivo resolver problemas de classificação de padrões. Mais tarde, após a introdução da função perda ε -insensitiva, foram também aplicadas a problemas de regressão (Smola e Schölkopf, 2004). A supremacia das MVSs em relação a outros algoritmos de DM, nomeadamente as RNAs, está patente na sua elevada capacidade de aprendizagem, designadamente quando aplicadas sobre dados de elevada complexidade (Tinoco et al., 2011b, c). Para uma melhor compreensão do algoritmo MVS recomenda-se a consulta de Chen e Councill (2003) e Smola et al. (1996).

O desempenho e a capacidade de generalização de uma MVS são fortemente condicionados pelos valores adotados para os hiperparâmetros C (parâmetro de penalização), ε (largura da zona ε -insensitiva) e os parâmetros do kernel. O problema da escolha dos valores ótimos para estes hiperparâmetros é ainda agravado pelo facto de a complexidade do modelo MVS (e por conseguinte da sua capacidade de generalização) estar dependente da combinação dos três parâmetros em simultâneo.

A escolha do tipo de kernel e respetivos parâmetros está normalmente relacionado com o domínio de aplicação e deverá refletir a distribuição dos valores de entrada (x) dos dados de treino (Cherkassky e Ma, 2004). No presente trabalho, foi adotado o kernel Gaussiano $K(x, x') = \exp(-\gamma \cdot \|x - x'\|^2)$, $\gamma > 0$. Para auxiliar a escolha dos valores dos diferentes hiperparâmetros, diversas abordagens têm sido propostas (Huang et al., 2007; Momma and Bennett, 2011; Frohlich and Zell, 2005). No presente trabalho, foram adotadas as heurísticas propostas por Cherkassky e Ma (2004). Assim, para C foi adotado o valor de $C=3$ e a largura da zona ε -insensitiva foi definida de acordo com $\varepsilon = \hat{\sigma}/\sqrt{N}$, onde $\hat{\sigma} = 1.5/N \times \sum_{i=1}^N (y_i - \hat{y}_i)^2$, \hat{y}_i é o valor previsto pelo algoritmo dos 3-vizinhos próximos e N representa o número de registos da base de dados. O parâmetro kernel γ foi definido usando uma grelha de procura entre $\{2^{-15}, 2^{-13}, \dots, 2^3\}$, e aplicando uma validação cruzada interna (i.e. aplicada sobre os dados de treino) de 10-fold (Hastie et al., 2009).

Todas as experiências foram conduzidas no ambiente estatístico R (R Development Core Team), com o auxílio de funções avançadas (particularmente as funções “mining” e “fit”) da biblioteca rminer (Cortez, 2010). Os dados utilizados para ajustar os modelos (variáveis de entrada) foram previamente normalizadas para uma média de zero e um desvio padrão de um. Posteriormente, antes de analisar as previsões, foi aplicada a respetiva função inversa (Hastie et al., 2009).

3. AVALIAÇÃO DOS MODELOS E CARACTERIZAÇÃO DA BASE DE DADOS

3.1 Avaliação e Interpretação dos Modelos

Na avaliação e comparação do desempenho dos diferentes modelos foram consideradas três métricas (Tinoco et al., 2011b): Desvio Médio Absoluto (MAD), Raiz Quadrada do Erro Médio Quadrado (RMSE) e Coeficiente de Correlação (R^2). Foram também construídas as respectivas curvas REC (Regression Curve Characteristic) propostas por Bi e Bennett, (2003). A capacidade de generalização dos modelos treinados foi medida através da implementação da abordagem Leave-One-Out (Hastie et al., 2009) e da repetição do processo de treino dos modelos 20 vezes. A capacidade de generalização final foi avaliada através do cálculo das métricas MAD, RMSE e R^2 para todos os N exemplos de teste.

Paralelamente à avaliação do desempenho de um modelo, a sua interpretação é também muito importante, particularmente se este resulta da aplicação de técnicas de DM. Nesse sentido, no presente estudo a interpretabilidade dos modelos foi baseada na aplicação de análises de sensibilidade detalhadas propostas por Cortez e Embrechts (2011). Este tipo de análises pode ser aplicado a qualquer modelo de DM, permitindo medir a importância relativa de cada atributo, bem como quantificar o seu efeito médio na respetiva variável de saída através da construção de curvas e superfícies VEC (Variable Effect Characteristic). Além disso, permitem quantificar o nível de interação entre atributos. No presente trabalho, durante a realização das análises de sensibilidade, foi adotada a medida gradiente e $L=12$ níveis (Cortez e Embrechts, 2011).

3.2 Base de Dados de Formulações Laboratoriais

Os dados utilizados durante a fase de treino/teste dos modelos provêm de um programa experimental laboratorial realizado na Universidade do Minho (Gomes Correia et al., 2009). No presente trabalho estudou-se a Q_u e respetiva deformabilidade de FLJG, quantificados experimentalmente através do ensaio de compressão uniaxial com medição local das deformações (Gomes Correia et al., 2009). Todas as amostras que compõe cada uma das bases de dados podem ser agrupadas por formulação em função dos valores da razão Água/Cimento (A/C), teor em cimento (massa de cimento/(massa de solo+massa de cimento); C), tipo de cimento (s) e propriedades do solo, isto é, percentagem de areia ($\%Areia$), percentagem de silte ($\%Silte$), percentagem de argila ($\%Argila$) e percentagem de matéria orgânica ($\%MO$). Adicionalmente, e tendo em conta o conhecimento existente relativo a misturas solo cimento, a relação entre a porosidade da mistura e o teor volumétrico de cimento ($n/(C_{iv})^d$) e a idade da mistura (t , dias) foram também consideradas como variáveis do modelo. As principais estatísticas das variáveis de entrada das bases de dados utilizadas no estudo da Q_u , E_0 , $E_{sec50\%}$ e E_{max} e $E_{tg50\%}$ podem ser consultadas respetivamente em Tinoco et al. (2011b), Tinoco et al. (2010), Tinoco et al. (2011c) e Tinoco et al. (2011a). A Tabela 1 resume o número de registos e de formulações de cada uma das bases de dados, bem como as principais estatísticas das propriedades mecânicas estudadas. Todos os solos utilizados na preparação das diferentes formulações foram caracterizados laboratorialmente (ver detalhes em Tinoco et al. (2011b)). Por último, há ainda a referir que todas as amostras foram preparadas utilizando três tipos de cimento: CEM I 42.5R ($s=0.20$), CEM II 42.5R ($s=0.20$) e CEM IV/A 35.5R ($s=0.25$).

Tabela 1 – Número de registos, formulações e principais estatísticas dos parâmetros numéricos de cada uma das bases de dados utilizadas

	Q_u (MPa)	E_0 (GPa)	$E_{sec50\%}$ (GPa)	$E_{tg50\%}$ (GPa)	E_{max} (GPa)
Número de registos	175	188	48	48	48
Número de formulações	35	9	8	8	8
Mínimo	0.76	0.25	1.50	1.30	1.50
Máximo	13.19	7.89	5.67	4.90	7.00
Média	5.20	2.36	3.17	2.76	3.44
Desvio Padrão	2.73	1.32	1.11	0.93	1.30

4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

Na Tabela 2 são apresentados os valores médios (e respetivo intervalo de confiança 95% de acordo com uma distribuição t-student) das métricas MAD, RMSE e R^2 , bem como dos hiperparâmetros e tempo de cálculo de todos os modelos treinados com algoritmo MVS. Os reduzidos valores de MAD e RMSE bem como um R^2 próximo da unidade mostram que os modelos treinados são capazes de estimar com elevada precisão ambas as propriedades mecânicas (resistência e deformabilidade) de FLJG. Este elevado performance pode ser visualmente observado na Figura 1a pela proximidade de todos os pontos em relação à linha diagonal que representa a previsão ideal. Nesta figura está também representada a curva REC do modelo MVS de previsão de Q_u (lida nos eixos vertical à direita e horizontal superior), observando-se um rápido aumento da precisão do modelo em função do erro tolerado. Esta curva mostra que 90% dos registos podem ser previstos pelo modelo com um desvio absoluto inferior a 1.5MPa. A relação observada na Figura 1a para os modelos MVS de previsão do E_0 , $E_{sec50\%}$, $E_{tg50\%}$ e E_{max} é muito semelhante a esta. Na Figura 1b representam-se as curvas REC dos modelos MVS de previsão da deformabilidade de FLJG. Também aqui é visível um rápido aumento da precisão dos modelos em função do desvio absoluto tolerado. Os resultados obtidos mostram que, conhecendo algumas propriedades da mistura e do solo natural, é possível estimar, ainda em fase de projeto, as propriedades mecânicas de FLJG ao longo do tempo com bastante precisão.

Tabela 2 – Métricas, hiperparâmetros e tempo de cálculo de todos os modelos ajustados com o algoritmo MVS (média e intervalo de confiança 95% de acordo com uma distribuição t-student)

	Q_u	E_0	$E_{sec50\%}$	$E_{tg50\%}$	E_{max}
MAD	0.55±0.00	0.17±0.00	0.15±0.01	0.15±0.00	0.18±0.00
RMSE	0.73±0.00	0.25±0.01	0.21±0.03	0.20±0.00	0.31±0.01
R2	0.93±0.00	0.96±0.00	0.96±0.01	0.95±0.00	0.94±0.00
gamma	0.55±0.00	0.17±0.00	0.15±0.01	0.15±0.00	0.18±0.00
ϵ	0.73±0.00	0.25±0.01	0.21±0.03	0.20±0.00	0.31±0.01
tempo	0.93±0.00	0.96±0.00	0.96±0.01	0.95±0.00	0.94±0.00

A avaliação de um modelo não deve ser fundamentada apenas pela sua capacidade previsional. A sua interpretação é também muito importante, particularmente em modelos resultantes da aplicação de técnicas de DM devido à elevada complexidade das expressões matemáticas envolvidas. Assim, no presente estudo, a interpretabilidade dos modelos foi efetuada através da realização de uma análise de sensibilidade detalhada.

A realização de uma análise de sensibilidade unidimensional, onde se faz alterar apenas uma variável de cada vez, mantendo as restantes nos respetivos valores médios, permitiu quantificar a importância relativa de cada atributo. A Figura 2 compara, para todos os modelos treinados, a importância relativa de cada variável, evidenciando que a relação

$n/(C_{iv})^d$ é aquela que apresenta maior impacto no estudo das propriedades mecânicas de FLJG (16% no estudo da resistência e cerca de 30% no estudo da deformabilidade). No caso do estudo da resistência, as variáveis t , C e $n/(C_{iv})^d$ correspondem às três variáveis chave. Já no estudo da deformabilidade, as propriedades do solo, nomeadamente a respetiva %Argila, seguem a relação $n/(C_{iv})^d$ nas variáveis com maior impacto. Uma observação também interessante, particularmente no estudo da deformabilidade, prende-se com o facto de a variável tempo apresentar um peso relativamente pequeno, exceto no estudo do E_0 . Mais adiante procurar-se-á justificar esta observação. Da análise da Figura 2 há ainda a salientar o menor efeito das propriedades do solo (particularmente a %argila) no estudo da resistência quando comparado com o estudo da deformabilidade.

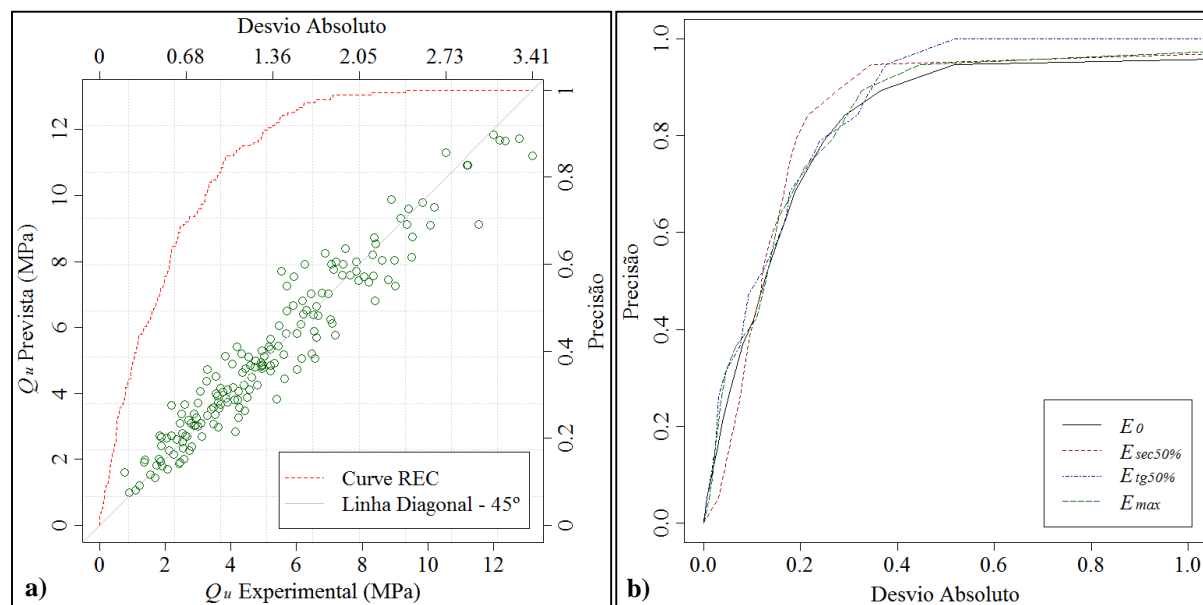


Figura 1 – **a)** Relação entre os valores experimentais da Q_u versus previstos pelo respetivo modelo MVS. A curva a traço interrompido representa a respetiva curva REC (lida no eixo superior horizontal e vertical à direita). **b)** Curvas REC dos modelos de previsão da deformabilidade de FLJG

A construção das curvas VEC permite complementar a informação obtida da análise da Figura 2 através da quantificação do efeito de cada atributo no estudo do comportamento mecânico de FLJG. Na Figura 3a são apresentadas as curvas VEC das três variáveis chave no estudo da resistência, evidenciando-se um efeito predominantemente não linear. Tal como expectável, tendo em conta o conhecimento empírico relativo a misturas solo-cimento, as variáveis t e C tem um efeito positivo na previsão da Q_u de FLJG. Por outro lado, o aumento da relação $n/(C_{iv})^d$ conduz a uma redução da resistência da mistura. Observa-se ainda que a curva VEC da t segue uma lei exponencial. Esta característica evidencia o maior impacto do tempo para idades recentes, tendendo posteriormente à estabilização para idades mais avançadas (acima dos 45 dias de cura). Há ainda a salientar o facto de a curva VEC do C manifestar um efeito mais pronunciado para teores em cimento superiores a 45%.

Nas Figuras 4 apresentam-se as curvas VEC para as duas variáveis mais relevantes no estudo da deformabilidade de FLJG ($n/(C_{iv})^d$ e %Argila), comparando-se o respetivo formato para cada um dos diferentes módulos. As curvas VEC da relação $n/(C_{iv})^d$, representadas na Figura 4a, evidenciam um efeito negativo no estudo da deformabilidade de FLJG, sendo mais pronunciado para valores de $n/(C_{iv})^d$ superiores a 60. Na Figura 4b representam-se as curvas VEC da %Argila para cada um dos diferentes módulos de deformabilidade estudados. Similarmente à relação $n/(C_{iv})^d$, também a %Argila evidencia um efeito negativo no estudo da

deformabilidade de FLJG. De realçar a tendência para estabilização para percentagem de argila acima dos 35%. Na parte final das curvas VEC da *%Argila* observa-se um aumento da rigidez com o aumento da percentagem de argila. Este comportamento não seria espectável, contudo pode ser justificado pela interação entre variáveis. Por exemplo, para solos com teores em argila muito elevados, a necessidade de adicionar grandes quantidades de cimento pode produzir amostras com módulos de deformabilidade superiores.


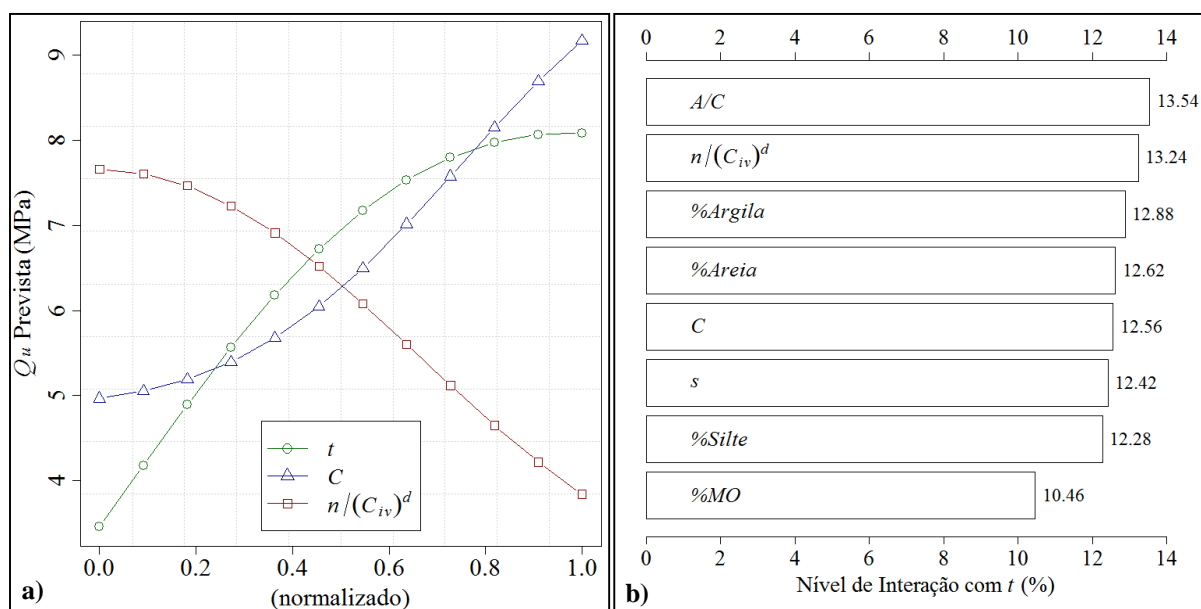


Figura 2 – Importância relativa de cada uma das variáveis no estudo das propriedades mecânicas de FLJG



Os resultados previamente apresentados foram obtidos através da realização de análises de sensibilidade unidimensionais, isto é, mantendo todas as variáveis nos respectivos valores médios e fazendo variar apenas uma variável de cada vez. Contudo, este tipo de condições raramente acontece em problemas reais. Assim, visando uma análise mais realista e detalhada, nos parágrafos seguintes são apresentadas e discutidas algumas observações resultantes da realização de uma análise de sensibilidade bidimensional, isto é, fazendo alterar duas variáveis em simultâneo.

Na Figura 3b é apresentado o nível de interação de todas as variáveis com t no estudo da Q_u , observando-se que a maior interação ocorre entre t e A/C (importância relativa de aproximadamente 14%). Esta observação mostra que a A/C apesar de ser apenas a quarta variável com maior impacto na previsão da Q_u de FLJG (ver Figura 2) não deverá ser menosprezada no estudo do comportamento mecânico deste material. Esta forte interação pode de certa forma ser explicada se se levar em consideração o facto de o aumento de resistência de misturas solo-cimento estar relacionado com a diminuição de água livre na mistura (processo de hidratação do cimento). Isto significa que para se obter a mesma resistência em amostras com A/C mais elevadas será necessário esperar mais tempo. Ou seja, o processo de endurecimento é mais rápido em amostras preparadas com A/C mais baixas.

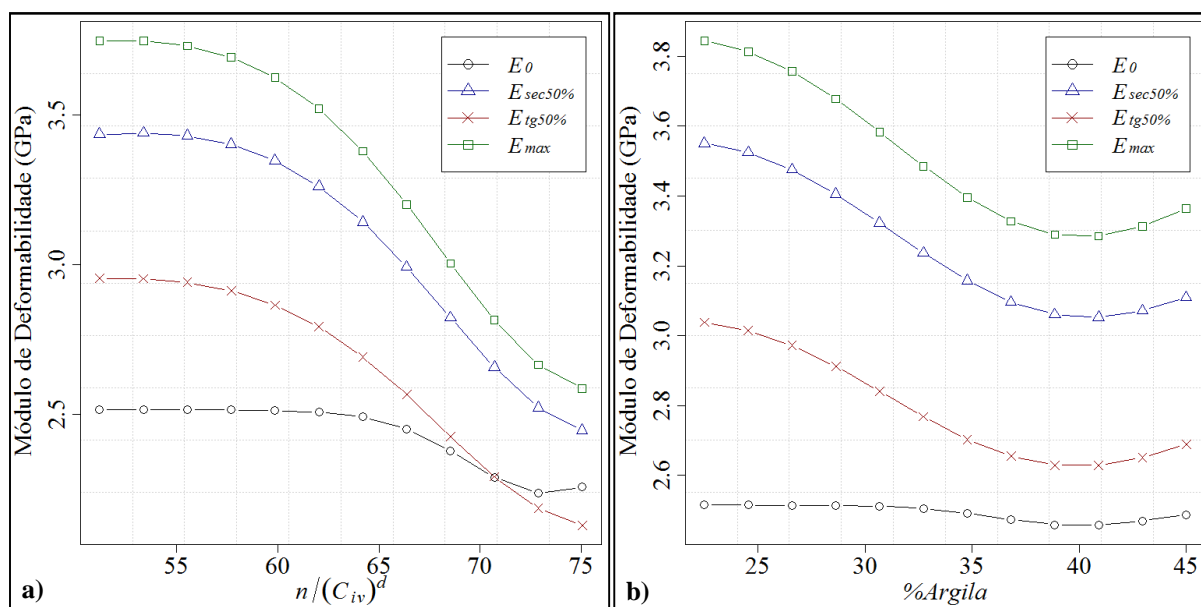


Figura 4 – Curvas VEC das variáveis chave segundo os modelos MVS de previsão da deformabilidade de FLJG, quantificadas por uma análise de sensibilidade unidimensional: **a)** Curvas VEC da variável $n/(C_{iv})^d$, **b)** curvas VEC da variável $\%Argila$

A superfície VEC apresentada na Figura 5a ilustra o efeito da interação entre t e A/C no estudo da Q_u , evidenciando a forte interação entre estas duas variáveis através do intervalo de variação da Q_u para as diferentes combinações entre t e A/C (desde 2MPa até 9MPa). Além disso, é possível observar que misturas com elevada A/C tendem a estabilizar para idades mais recentes. A superfície VEC da interação entre t e $n/(C_{iv})^d$ (ver Figura 5b) mostra que o efeito do t no estudo da Q_u é mais pronunciado em amostras com uma relação $n/(C_{iv})^d$ inferior. Isto significa que amostras com elevada porosidade (ou baixos teores em cimento) apenas sofrem um ligeiro aumento da resistência ao longo do tempo. A Figura 5b evidencia também o forte impacto da interação entre t e $n/(C_{iv})^d$ no estudo da Q_u de FLJG.

Na Tabela 3 é apresentado o nível de interação de todas as variáveis com $n/(C_{iv})^d$ para cada um dos quatro módulos estudados, quantificado por uma análise de sensibilidade bidimensional. A $\%Argila$ e t são as variáveis que globalmente apresentam a maior interação

com $n/(C_{iv})^d$ no estudo da deformabilidade de FLJG. A forte interação entre t e $n/(C_{iv})^d$ permite de certa forma justificar a menor importância relativa da t observada na Figura 2. O contorno VEC apresentado na Figura 6a ilustra o efeito da interação entre $n/(C_{iv})^d$ e a %Argila no estudo do $E_{tg50\%}$, evidenciando que os maiores valores de $E_{tg50\%}$ são obtidos em amostras com $n/(C_{iv})^d$ inferior e preparadas com solos com baixos teores em argila. Verifica-se também que $E_{tg50\%}$ é mais sensível a variações de $n/(C_{iv})^d$ do que ao teor em argila do solo. A mesma representação para os restantes módulos de deformabilidade é em tudo semelhante. Na Figura 6b ilustra-se o efeito no estudo do E_0 da interação entre $n/(C_{iv})^d$ e a t da mistura, onde é possível verificar o quase nulo impacto da t no estudo do E_0 em amostras com reduzidos valores de $n/(C_{iv})^d$.

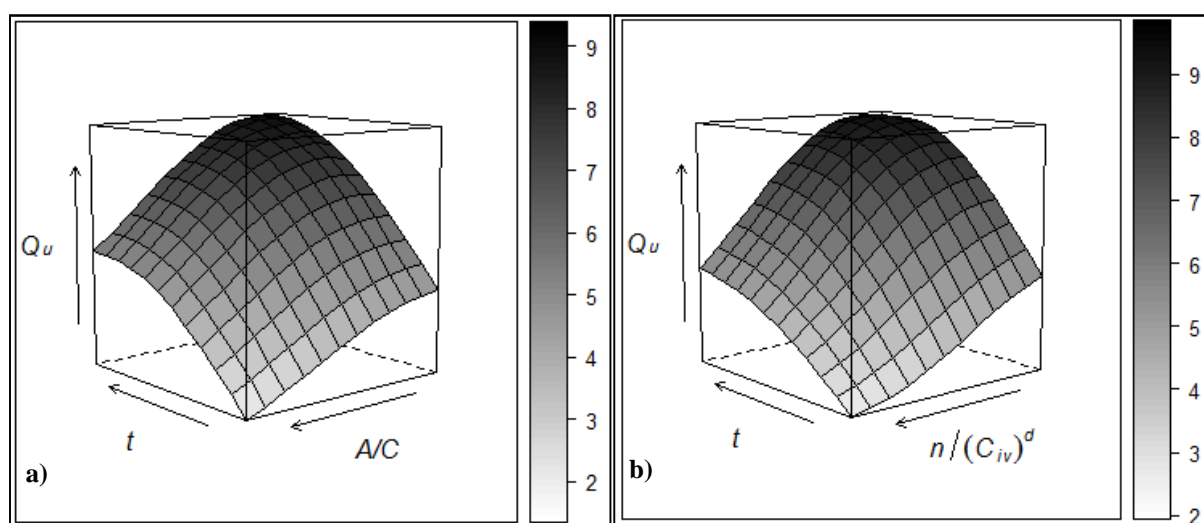


Figura 5 – Superfícies VEC da interação entre: **a)** t e A/C e **b)** t e $n/(C_{iv})^d$ no estudo da Q_u de FLJG, quantificadas por uma análise de sensibilidade bidimensional

Tabela 3 – Nível de interação de todas as variáveis com $n/(C_{iv})^d$, de acordo com os modelos MVS de previsão do E_0 , $E_{sec50\%}$, $E_{tg50\%}$ e E_{max} de FLJG, após a aplicação de uma análise de sensibilidade bidimensional

		t	C	A/C	%Areia	%Silte	%Argila	%MO
$n/(C_{iv})^d$	E_0	21.22	10.60	14.48	15.86	10.45	17.94	9.45
	$E_{sec50\%}$	15.57	13.49	13.18	14.92	12.44	16.31	14.10
	$E_{tg50\%}$	15.34	13.20	13.39	15.00	12.46	16.48	14.13
	E_{max}	15.80	13.77	12.89	14.90	12.42	16.16	14.07

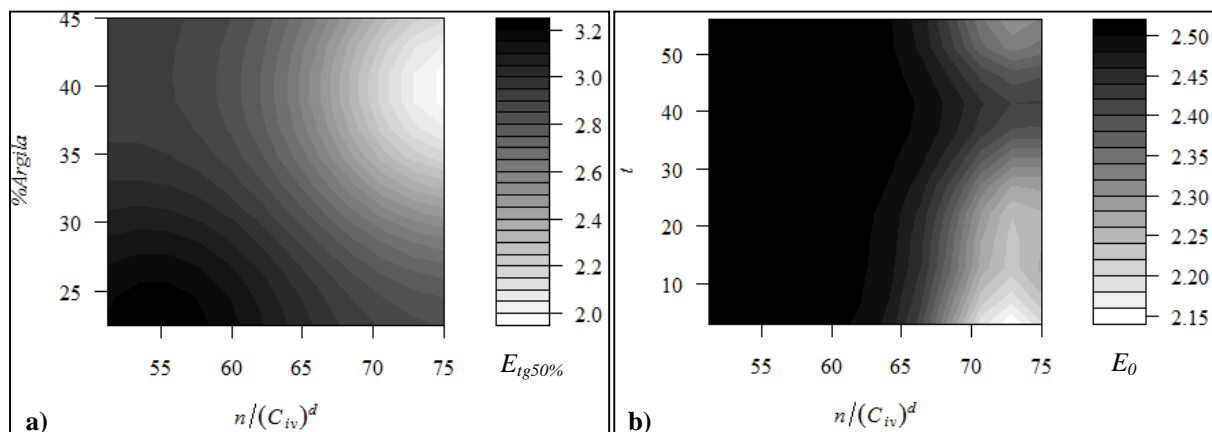


Figura 6 – Contorno VEC da interação entre: **a)** $n/(C_{iv})^d$ e %Argila no estudo do $E_{tg50\%}$ de FLJG e **b)** $n/(C_{iv})^d$ e t no estudo do E_0 de FLJG, quantificadas por uma análise de sensibilidade bidimensional

5. CONCLUSÕES

No contexto da tecnologia de Jet Grouting (JG) a principal limitação está relacionada com a ausência de modelos racionais de dimensionamento para a previsão das propriedades mecânicas da mistura obtida. Atualmente, esta tarefa é essencialmente realizada considerando os resultados de ensaios laboratoriais e expressões empíricas. No entanto, nas fases iniciais de projeto, principalmente em obras geotécnicas de pequena envergadura, a escolha dos valores a adotar para cada um dos parâmetros é baseada em informação muito escassa. Assim, o uso de dados de projetos já realizados pode ser visto como uma alternativa para ultrapassar este problema. A aplicação de técnicas de Data Mining (DM) a dados bem organizados coletados em grandes obras geotécnicas pode fornecer uma importante base para o desenvolvimento de modelos que poderão ser muito úteis em futuros projetos.

No presente trabalho, foram propostos modelos racionais de previsão da resistência à compressão uniaxial (Q_u) e dos diferentes módulos de deformabilidade, isto é, módulo de elasticidade inicial (E_0), módulo de deformabilidade secante a 50% da tensão de rotura ($E_{sec50\%}$), módulo de deformabilidade tangente a 50% da tensão de rotura ($E_{tg50\%}$) e módulo de deformabilidade máximo (E_{max}), de Formulações Laboratoriais de Jet Grouting (FLJG) ao longo do tempo por aplicação de técnicas de DM. Os modelos apresentados são capazes de prever com fiabilidade a Q_u e o E_0 entre os 3 a 56 dias, bem como o $E_{sec50\%}$, $E_{tg50\%}$ e E_{max} entre 28 e 84 dias de FLJG, preparadas com solos argilosos contendo diferentes percentagens de areia, silte, argila e matéria orgânica. Os resultados obtidos mostraram que o algoritmo Máquinas de Vetores de Suporte (MVS) é capaz de aprender as complexas relações entre as propriedades mecânicas (resistência e deformabilidade) de FLJG e as diferentes variáveis intervenientes. Além disso, a realização de uma análise de sensibilidade detalhada sobre os modelos treinados possibilitou uma melhor compreensão dos modelos, isto é, do comportamento das misturas. Este tipo de análise permitiu estabelecer algumas importantes observações. A relação entre a porosidade da mistura e o teor volumétrico de cimento ($n/(C_{iv})^d$) foi identificada como a variável chave no estudo das propriedades mecânicas de FLJG. Adicionalmente, no estudo da Q_u , a idade e o teor em cimento da mistura apresentam também uma importância significativa. Já no estudo da deformabilidade, as propriedades do solo, principalmente o seu teor em argila, assumem um papel preponderante. Observou-se ainda um comportamento predominantemente não linear das variáveis chave no estudo de ambas as propriedades mecânicas. Particularmente, o fator tempo segue uma lei exponencial,

corroborando o conhecimento empírico relativo a misturas solo-cimento. Por fim, observou-se uma forte interação entre a idade da mistura e a relação água/cimento na previsão da Q_u . No estudo da deformabilidade verificou-se uma forte interação do teor em argila do solo e da idade da mistura com $n/(C_{iv})^d$.

Face ao excelente desempenho dos modelos treinados, não apenas em termos de capacidade previsionais mas também em termos de coerência com o atual conhecimento empírico relativo ao comportamento mecânico de FLJG, pode-se concluir que tais modelos podem ser utilizados para descrever com elevado grau de fiabilidade o conhecimento empírico relativo a este tipo de material e servir de apoio ao dimensionamento das respectivas propriedades mecânicas (resistência e deformabilidade). Julga-se que o estudo realizado é uma contribuição para o aumento do conhecimento sobre misturas de solo-cimento para obras de JG, resultando numa economia de formulações laboratoriais ao nível do projeto.

Em trabalhos futuros, estas ferramentas de DM serão aplicadas no desenvolvimento de modelos racionais de previsão das propriedades mecânicas (resistência e deformabilidade) de amostras extraídas diretamente de colunas de JG. Serão ainda aplicadas as mesmas metodologias na previsão do diâmetro de colunas de JG.

6. AGRADECIMENTOS

Os autores gostariam de agradecer à Fundação para a Ciência e a Tecnologia (FCT) pelo apoio financeiro no âmbito do projeto PEst-OE/ECI/UI4047/2011 e pela bolsa de doutoramento SFRH/BD/45781/2008. Agradece-se também à empresa Tecnasol-FGE por todo o interesse e apoio prestado.

REFERÊNCIAS

- Bi, J. e Bennett, K., Regression Error Characteristic Curves (CD-ROM), *Proc. of 20th International Conference on Machine Learning*, AAAI Press, Washington, DC, 40-50 (2003).
- Chen, Y. e Councill, I., An Introduction to Support Vector Machines: A Review, *AI Magazine*, AAAI Press, **24(2)**, 105-107 (2003).
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C. e Wirth, R., *CRISPDM1.0: Step-by-Step Data Mining Guide*, CRISP-DM consortium, (2000).
- Cherkassky, V. e Ma, Y., Practical Selection of SVM Parameters and Noise Estimation for SVM Regression, *Neural Networks*, Elsevier, **17(1)**, 113-126 (2004).
- Cortes, C. e Vapnik, V., Support Vector Networks, *Machine Learning*, Springer, **20(3)**, 273-297 (1995).
- Cortez, P., Data Mining with Neural Networks and Support Vector Machines Using the R/rminer Tool. *Advances in Data Mining – Applications and Theoretical Aspects 10th Industrial Conference on Data Mining (ICDM 2010)*, *Lecture Notes in Artificial Intelligence* 6171, Springer, Berlin, Alemanha, 572-583 (2010).
- Cortez, P. e Embrechts, M., Opening Black Box Data Mining Models Using Sensitivity Analysis, *Proc. of the 2011 IEEE Symposium on Computational Intelligence and Data Mining (CIDM 2011)*, IEEE, Paris, França, 341-348 (2011).
- Croce, P. e Flora, A., Analysis of Single-fluid Jet Grouting. *Géotechnique*, **51**, 905-906 (2001).
- Fayyad, U., Piatetsky-Shapiro, G. e Smyth, P., The KDD Process for Extracting Useful Knowledge from Volumes of Data. *Communications of the ACM*, ACM, **39(11)**, 27-34 (1996).

Frohlich, H. e Zell, A., Efficient Parameter Selection for Support Vector Machines in Classification and Regression via Model-Based Global Optimization, *Neural Networks*, IEEE, **3**, 1431-1436 (2005).

Gazaway, H. e Jasperse, B., Jet grouting in Contaminated Soils. *Proc. of Grouting, Soil Improvement and Geosynthetics (GSP 30)*, ASCE, New Orleans, LA, USA, 206-214 (1992).

Gomes Correia, A., Valente, T., Tinoco, J., Falcão, J., Barata, J., Cebola, D., e Coelho, S., Evaluation of Mechanical Properties of Jet Grouting Columns using Different Test Methods, *Proc. of 17th International Conference on Soil Mechanics and Geotechnical Engineering*, IOS Press, Alexandria, Egito, 2179-2171 (2009).

Goh, A. e Goh, S., Support Vector Machines: Their use in Geotechnical Engineering as Illustrated using Seismic Liquefaction Data, *Computers and Geotechnics*, Elsevier, **34(5)**, 410-421 (2007).

Hastie, T., Tibshirani, R. e Friedman, J., *The Elements of Statistical Learning: Data Mining, Inference, and Prediction - 2nd edition*, Springer-Verlag, (2009).

Huang, C., Lee, Y., Lin, D. e Huang, S., Model Selection for Support Vector Machines via Uniform Design. *Computational Statistics & Data Analysis*, Elsevier, **52(1)**, 335-346 (2007).

Kirsh, F. e Wolfgang, S., Ground Improvement and its Numerical Analysis, *Proc. of 15th International Conference on Soil Mechanics and Geotechnical Engineering*, AA Balkema Publishers, Atenas, Grécia, **3**, 1775-1778 (2001).

Lee, F., Lee, Y., Chew, S. e Yong, K., Strength and Modulus of Marine Clay-Cement Mixes, *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, **131(2)**, 178-186 (2005).

Liu, S., Zhang, D., Liu, Z. e Deng, Y., Assessment of Unconfined Compressive Strength of Cement Stabilized Marine Clay, *Marine Georesources & Geotechnology*, Taylor & Francis, **26(1)**, 19-35 (2008).

Miranda, T., Gomes Correia, A., Santos, M., Sousa, L. e Cortez, P., New Models for Strength and Deformability Parameter Calculation in Rock Masses Using Data-Mining Techniques, *International Journal of Geomechanics*, ASCE, **11**, 44-58 (2011).

Momma, M. e Bennett, K., A Pattern Search Method for Model Selection of Support Vector Regression, *Proceedings of the SIAM International Conference on Data Mining*, Philadelphia: SIAM, Arizona, USA, 261-274 (2011).

Narendra, B., Sivapullaiah, P., Suresh, S. e Omkar, S., Prediction of Unconfined Compressive Strength of Soft Grounds using Computational Intelligence Techniques: A Comparative Study, *Computers and Geotechnics*, Elsevier, **33(3)**, 196-208 (2006).

Nikbakhtan, B. e Ahangari, K., Field Study of the Influence of Various Jet Grouting Parameters on Soilcrete Unconfined Compressive Strength and its Diameter, *International Journal of Rock Mechanics and Mining Sciences*, Elsevier, **47**, 685-689 (2010).

R Development Core Team., *R: a Language and Environment for Statistical Computing*, R Foundation for Statistical Computing, Vienna, Austria, <http://www.R-project.org>, acedido em 07/12/2011 (2009).

Smola, A. e others, *Regression Estimation with Support Vector Learning Machines*, Master's Thesis, Technische Universit at Munchen, (1996).

Smola, A. e Schölkopf, B., A Tutorial on Support Vector Regression, *Statistics and Computing*, Springer, **14(3)**, 199-222 (2004).

Tinoco, J., Gomes Correia, A. e Cortez, P., Application of Data Mining Techniques to Estimate Elastic Young Modulus Over Time of Jet Grouting Laboratory Formulations, *Proc. of 1st International Conference on Information Technology in Geo-Engineering*, IOS Press, Shanghai, Chine, 92-100 (2010).

Tinoco, J., Gomes Correia, A. e Cortez, P., Using Data Mining Techniques to Predict Deformability Properties of Jet Grouting Laboratory Formulations over Time, *Proc. of 15th Portuguese Conference on Artificial Intelligence*, L. Antunes and H.S. Pinto (Eds.), Springer-Verlag, Guimarães, Portugal, 491–505 (2011a).

Tinoco, J., Gomes Correia, A. e Cortez, P., Application of Data Mining Techniques in the Estimation of the Uniaxial Compressive Strength of Jet Grouting Columns over Time, *Construction and Building Materials*, Elsevier, **25(3)**, 1257-1263 (2011b).

Tinoco, J., Gomes Correia, A. e Cortez, P., Using Data Mining Techniques to Predict Deformability Properties of Jet Grouting Laboratory Formulations over Time, *Progress in Artificial Intelligence*, Springer, 491-505 (2011c).

Vapnik, V. N., *The Nature of Statistical Learning Theory - 2nd edition*, Springer-Verlag, New York, USA, (2000).

Xanthakos, P., Abramson, L. e Bruce, D., *Ground Control and Improvement*. Wiley-Interscience, (1994).

Welsch, J. e Burke, G., Jet Grouting – Uses For Soil Improvement, *Proceedings of Geotechnical Engineering Congress (GSP No. 27)*, 334-345 (1991).